

APLICAÇÃO DE ALGORITMOS GENÉTICOS PARA A ESTIMAÇÃO DE ESTADO EM REDES DE DISTRIBUIÇÃO CONSIDERANDO MEDIDAS AGREGADAS E PERDAS NA BAIXA TENSÃO

Fernanda Decothé Andrade Torres

Julio Cesar Stacchini de Souza

Rainer Zanghi

Andre Abel Augusto

João Victor Daher Daibes

Milton Brown Do Coutto Filho

Universidade Federal Fluminense – UFF

Rua Passo da Pátria, 156 – Niterói, RJ – 24210-240

fedecothe@id.uff.br

julio@ic.uff.br

rzanghi@id.uff.br

aaugusto@id.uff.br

joaovdd@id.uff.br

mbrown@ic.uff.br

RESUMO

A Estimação de Estado é responsável por processar um conjunto redundante de medidas e obter a condição operativa mais provável do sistema de potência, sendo essencial para o sucesso das modernas funções de automação e controle em sistemas de distribuição. Medições em tempo real são geralmente escassas em sistemas de distribuição, o que tem mudado com a crescente implantação de muitos medidores inteligentes. No entanto, os dados dos medidores inteligentes devem ser agregados como uma única medição de carga em um nó da rede de média tensão, sem representar a rede de baixa tensão, negligenciando as perdas nesse nível. Este artigo apresenta uma metodologia baseada em algoritmos genéticos para a Estimação de Estado da distribuição, utilizando medições agregadas de medidores inteligentes e determinando as perdas na rede de baixa tensão durante o processo evolutivo. Simulações com um sistema trifásico desequilibrado, de 34 barras, ilustram a abordagem proposta.

PALAVRAS CHAVE. Sistemas de distribuição, Estimação de estado, Otimização.

Energia; Otimização Combinatória; Metaheurísticas.

ABSTRACT

State Estimation is responsible for processing a set of redundant measurements and obtaining the most likely operating condition of power systems, being an essential tool for the success of modern automation and control functions in distribution systems. Real-time measurements are usually scarce in distribution systems, but this has been changing with the deployment of many smart meters in the power grid. However, data from smart meters must be aggregated as a single load measurement at a given medium voltage system node, without representing the low voltage network and therefore neglecting power losses at this level. This paper presents a genetic-based methodology for distribution State Estimation, using aggregated smart meter measurements and considering the power losses at the low voltage network, which are determined during the evolutionary process. Simulations with a three-phase, unbalanced 34-bus test system illustrate the proposed approach.

KEYWORDS. Distribution systems. State estimation. Optimization.

Energy; Combinatorial Optimization; Metaheuristics.

1. Introdução

Os sistemas de distribuição, tradicionalmente projetados como redes elétricas passivas, têm passado por diversas transformações, de modo a se adequar ao conceito de redes elétricas inteligentes. Tais mudanças são influenciadas por diferentes fatores, tais como: introdução de geração distribuída conectada diretamente à rede de distribuição, substituição de fontes de geração convencional por fontes de geração renovável, introdução de novas tecnologias que beneficiarão os sistemas de supervisão e controle (ex: novos dispositivos eletrônicos e sistemas de medição inteligente), entre outros. De acordo com [Galvin e Yeager 2009], [Dugan et al. 2010], [Heydt 2010], [Arritt e Dugan 2011], algumas das características comumente associadas a uma rede de distribuição inteligente são:

- Presença de fontes de geração distribuída e renovável;
- Capacidade de detectar, analisar e responder a distúrbios (*self-healing*);
- Fácil integração (*plug and play*) de diferentes tipos de fontes e cargas;
- Automação e controle da rede de distribuição;
- Uso eficiente dos ativos presentes na rede.

O sucesso na implementação de tais características requer o investimento em modelos e técnicas que permitam efetivamente monitorar e controlar a rede elétrica [OSI 2024]. Neste contexto, a supervisão confiável do estado de operação da rede é de crucial importância, uma vez que o conhecimento de tal estado é ponto de partida para diversas análises e tomadas de decisão. A Estimação de Estado (EE) é a função de análise responsável por determinar o estado de operação mais confiável de uma rede elétrica, sendo já amplamente utilizada na supervisão de sistemas de transmissão de energia elétrica e estando presente no projeto e implementação dos Centros de Operação de Sistemas modernos. Esta função responde pela construção de uma base de dados completa e confiável, necessária para o uso de outras funções, tais como as de análise, controle e otimização.

A EE tende a se tornar cada vez mais presente nos Centros de Operação da Distribuição (COD), como uma ferramenta essencial [Lefebvre et al. 2014] para o sucesso das modernas funções de automação e controle de sistemas de distribuição, tais como o controle do perfil de tensão da rede, reconfiguração ótima de alimentadores, detecção de ilhamento em redes com geração distribuída, entre outras. Entretanto, a EE em sistemas de distribuição apresenta ainda grandes desafios, muitos deles diferentes dos encontrados em sistemas de transmissão, a começar pela insuficiência de medidas coletadas na rede, o que impede que o pleno funcionamento da função EE. Em geral, as medidas coletadas são complementadas por pseudomedidas extraídas de bases de dados históricas [Singh et al. 2009], as quais apresentam grande incerteza e acrescentam pouco ou nenhum valor aos resultados da EE.

No que diz respeito à EE em redes de distribuição, existe grande interesse na supervisão da condição de operação dos sistemas de média tensão (MT). Porém, isto é dificultado pelo limitado número de dispositivos de medição instalados na MT. Na maioria dos casos, a instalação de dispositivos de medição é limitada à subestação que conecta os sistemas de alta e média tensão (AT/MT), mas raramente nos transformadores de média para baixa tensão (MT/BT), sendo que estes últimos são encontrados em muito maior quantidade na rede de distribuição [Della Giustina et al. 2014]. Por outro lado, nos últimos anos tem crescido muito a quantidade de medidores inteligentes instalados no nível de baixa tensão por diversas empresas ao redor do mundo, inclusive no Brasil. Um medidor inteligente pode medir a potência ativa e reativa das cargas a cada 30 minutos, dentre outras possibilidades [Chen et al. 2016]. Como resultado disso, um grande volume de dados começa a estar disponível, restando ainda o investimento no desenvolvimento de métodos que permitam a sua efetiva utilização. Uma preocupação em relação aos dados de medidores inteligentes (MI) é o impacto na privacidade dos consumidores [Chen et al. 2016], existindo a

tendência de se estabelecer restrições no acesso a tais dados. Neste sentido, apenas dados agregados de MI podem ser acessados pelos operadores de redes de distribuição, de forma a preservar a privacidade dos indivíduos, os quais não podem ser identificados. Porém, é reconhecido que tal restrição pode limitar o uso dos dados e impactar a supervisão do sistema de distribuição pela função EE, que depende de adequada redundância de medidas para processamento. É reconhecido também que o uso dos dados de MI permite uma representação da carga (potência ativa e reativa) dos transformadores MT/BT que é mais precisa que a utilização de dados históricos. Por outro lado, isto traz como inconveniente o fato de que a agregação das cargas dos consumidores que estão a jusante do transformador MT/BT negligencia a perda de potência ao longo da rede de baixa tensão, levando a uma imprecisão no valor da medida agregada a ser processada pela EE.

Este artigo apresenta uma metodologia para a EE em redes de distribuição empregando medidas de MI agregadas e considerando as perdas nas redes de baixa tensão. A metodologia proposta emprega um algoritmo genético (AG) para a minimização da função objetivo da EE quando esta processa dados de MI agregados nas barras de média tensão. Cada indivíduo (cromossomo) do AG é representado por um vetor contendo as variáveis de decisão, que são as perdas nas redes de baixa tensão. A EE é então executada para cada indivíduo, com cada medida agregada sendo corrigida utilizando o valor de perda de potência estimada pelo AG para a rede de baixa tensão correspondente. A função aptidão do AG é definida em termos de um parâmetro que relaciona a função objetivo da EE e indica a melhora da qualidade do processo de estimação de estado a partir da estimação das perdas. Testes realizados com um sistema de distribuição trifásico desequilibrado de 34 barras mostram a efetividade da metodologia proposta.

2. Estimação de Estado

A EE atua como um filtro para suavizar erros estatisticamente pequenos, corriqueiros, inerentes à medição, bem como, e principalmente, suavizar erros grosseiros eventuais, causados pelo funcionamento inadequado do sistema de aquisição de dados. Como parte do processo de estimação, determina-se também a configuração atual da rede elétrica e sua observabilidade. O problema de estimação é em geral formulado assumindo-se as seguintes hipóteses:

- Os erros das medidas disponíveis para processamento (fluxos e injeções de potência, magnitudes de tensão) são estatisticamente pequenos;
- O sistema de medição fornece dados redundantes em termos de quantidade, tipo e distribuição na rede sob supervisão. Tal redundância refere-se ao excedente de medidas disponíveis em relação a um número mínimo necessário para estimar todas as variáveis de estado do sistema;
- A configuração atual da rede está correta (i.e., não há erros nas indicações de status de chaves/disjuntores) e seus parâmetros são perfeitamente conhecidos.

O modelo não-linear que descreve a relação entre estado e sua observação (medidas) caracteriza-se pela seguinte equação:

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \mathbf{v} \quad (1)$$

onde:

$\mathbf{x}$ – vetor de estado ($n \cdot 1$), composto pelos ângulos de fase e magnitudes das tensões das barras;

$\mathbf{z}$ – vetor das medidas cruas ($m \cdot 1$);

$\mathbf{h}$ – vetor das equações das medidas ($m \cdot 1$), para a configuração atual da rede;

$\mathbf{v}$ – vetor dos erros de medição ($m \cdot 1$), para o qual admite-se a distribuição normal de média zero e matriz de covariância $\mathbf{R}$.

A função-objetivo para o processo de filtragem do estado através do método dos mínimos quadrados ponderados (MQP) é dada por:

$$J(\mathbf{x}) = [\mathbf{z} - \mathbf{h}(\mathbf{x})]^t \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x})] \quad (2)$$

O estado estimado $\hat{\mathbf{x}}$ que minimiza $J(\mathbf{x})$ pode ser obtido iterativamente através de [Abur e Gómez-Expósito 2004]:

$$\begin{aligned} \mathbf{G}\Delta\mathbf{x} &= \mathbf{H}^t \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x}^{(k)})] \\ \mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \Delta\mathbf{x} \end{aligned} \quad (3)$$

onde: $\mathbf{G} = \mathbf{H}^t \mathbf{R}^{-1} \mathbf{H}$ – matriz de ganho ($n \times n$); $\mathbf{H} = \frac{\partial \mathbf{h}}{\partial \mathbf{x}}$ – matriz Jacobiano ($m \times n$), calculada em $\mathbf{x} = \mathbf{x}^{(k)}$; k – contador de iterações.

Uma vez concluído o processo de filtragem da EE e obtido o estado estimado $\hat{\mathbf{x}}$, o valor final da função-objetivo, associado à qualidade do resultado da EE, é obtido como em (4).

$$J(\hat{\mathbf{x}}) = [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})]^t \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (4)$$

No presente trabalho, as medidas processadas correspondem a fluxos de potência ativa e reativa em alguns ramos da rede, magnitudes de tensão, com injeções de potência ativa e reativa representando as medidas agregadas de MI. As correntes nos ramos da rede foram consideradas como variáveis de estado. Maiores detalhes sobre a teoria de EE em sistemas de potência podem ser encontrados em [Monticelli 1999], [Abur e Gómez-Expósito 2004], enquanto detalhes sobre o modelo de estimador de estado empregado neste trabalho podem ser encontrados em [Baran e Kelley 1995].

3. Metodologia Proposta

A metodologia proposta para EE em sistemas de distribuição utiliza em algumas barras da rede de média tensão, medidas obtidas a partir da agregação de dados de MI coletados no nível de baixa tensão. Um algoritmo genético é empregado para determinar valores de perdas elétricas na rede de baixa tensão, com o objetivo de corrigir os valores de medidas agregadas e, consequentemente, melhorar os resultados obtidos pela estimação de estado. As principais características da metodologia proposta são apresentadas a seguir.

3.1 Formulação do problema

Na metodologia proposta, o problema tratado neste trabalho é visto como um problema de otimização descrito como:

$$\begin{aligned} \text{Min } J(\mathbf{x}, \Delta\text{Perd}) &= [\mathbf{z}_m - \mathbf{h}_m(\mathbf{x})]^t \mathbf{R}_m^{-1} [\mathbf{z}_m - \mathbf{h}_m(\mathbf{x})] + \\ &+ [(\mathbf{z}_{MI} + \Delta\text{Perd}) - \mathbf{h}_{MI}(\mathbf{x})]^t \mathbf{R}_{MI}^{-1} [(\mathbf{z}_{MI} + \Delta\text{Perd}) - \mathbf{h}_{MI}(\mathbf{x})] \end{aligned} \quad (5)$$

$$\text{sujeito a } \Delta\text{Perd}_j \leq f p_j \times z_{MI}(j), \quad \text{para } j \in \Omega_{MI}$$

onde:

$\mathbf{x}$ – vetor de estado;

$\mathbf{z}_m$ – vetor de medidas coletadas diretamente no nível de média tensão;

$\mathbf{z}_{MI}$ – vetor de medidas obtidas a partir da agregação de dados de MI da baixa tensão;

$\mathbf{h}_m(x)$ – vetor de equações das medidas coletadas na média tensão;
 $\mathbf{h}_{MI}(x)$ – vetor de equações das medidas obtidas a partir da agregação de dados de MI;
 $\mathbf{R}_m$ – matriz de covariância das medidas coletadas na média tensão;
 $\mathbf{R}_{MI}$ – matriz de covariância das medidas obtidas a partir da agregação de dados de MI;
 $\Delta\mathbf{Perd}$ – vetor de perdas nas redes de baixa tensão em que ocorre a agregação de dados de MI;
 fp_j – fator que representa o percentual máximo esperado da perda na j -ésima rede de baixa tensão em relação à carga total agregada;
 Ω_{MI} – conjunto contendo as barras de média tensão cujas medidas de injeção correspondem às medidas de MI agregadas.

Para obter a função objetivo apresentada em (5), aquela apresentada em (2) foi desmembrada, separando o termo correspondente às medidas obtidas pela agregação de dados de MI do termo correspondente às medidas coletadas diretamente na média tensão. No segundo termo de (5) é possível perceber que os componentes do vetor de perdas na baixa tensão, $\Delta\mathbf{Perd}$, são usados para corrigir os valores de medidas obtidas pela agregação de MI. No problema de otimização apresentado, não apenas o vetor de estado $\mathbf{x}$ deve ser determinado, como também o vetor $\Delta\mathbf{Perd}$, este último tendo impacto direto na qualidade do estado estimado. A restrição imposta para os componentes do vetor $\Delta\mathbf{Perd}$ tem o objetivo de limitar o espaço de busca pela melhor solução do problema. A escolha dos fatores fp_j pode ser feita com base na experiência ou utilizando valores típicos em função de perdas máximas usuais em redes de baixa tensão (expressa em por cento, como função da carga total).

3.2 Codificação da solução

As variáveis de decisão consistem no vetor $\Delta\mathbf{Perd}$, cujos elementos contêm valores de potência ativa e reativa correspondentes às perdas na baixa tensão. Um vetor $\Delta\mathbf{Perd}$ representa um cromossomo (indivíduo) da população do AG, esquematizado na Figura 1 para N_{pop} indivíduos e considerando N_{MI} barras com cargas cujas medidas de injeção não agregam as perdas. O cromossomo $\Delta\mathbf{Perd}$ é composto pelos valores propostos pelo AG para as perdas, estas representadas como injeções adicionais de potência ativa e reativa em cada barra cujas medidas advêm de MI.

	População						
$\Delta\mathbf{Perd}_1$	$\Delta P_1^{(1)}$	$\Delta Q_1^{(1)}$	$\Delta P_2^{(1)}$	$\Delta Q_2^{(1)}$	...	$\Delta P_{N_{MI}}^{(1)}$	$\Delta Q_{N_{MI}}^{(1)}$
$\Delta\mathbf{Perd}_2$	$\Delta P_1^{(2)}$	$\Delta Q_1^{(2)}$	$\Delta P_2^{(2)}$	$\Delta Q_2^{(2)}$	...	$\Delta P_{N_{MI}}^{(2)}$	$\Delta Q_{N_{MI}}^{(2)}$
...	...	...	...	...	...	...	...
$\Delta\mathbf{Perd}_{N_{pop}}$	$\Delta P_1^{(N_{pop})}$	$\Delta Q_1^{(N_{pop})}$	$\Delta P_2^{(N_{pop})}$	$\Delta Q_2^{(N_{pop})}$	...	$\Delta P_{N_{MI}}^{(N_{pop})}$	$\Delta Q_{N_{MI}}^{(N_{pop})}$

Figura 1 - População do AG

3.3 Função de aptidão

A partir do problema de otimização apresentado na Seção 3.1, a seguinte função de aptidão, a ser minimizada, pode ser formulada:

$$FA = \frac{J(\mathbf{x}, \Delta\mathbf{Perd})}{J(\mathbf{x}, \mathbf{0})} \times 100 \quad (6)$$

onde $J(\mathbf{x}, \Delta\mathbf{Perd})$ corresponde à função objetivo apresentada em (5) e $J(\mathbf{x}, \mathbf{0})$ representa a função objetivo avaliada quando as medidas agregadas de MI são processadas sem considerar o acréscimo das perdas, ou seja, quando o vetor $\Delta\mathbf{Perd}$ tem todos os seus elementos iguais a zero. O vetor $\Delta\mathbf{Perd}$ terá dimensão $2 \times N_{MI}$, sendo função do número de barras em que são consideradas medidas de MI agregadas.

Vale destacar que a restrição indicada em (5), para a faixa de valores considerada para a correção das perdas, é automaticamente respeitada durante o processo evolutivo, pela rejeição de indivíduos que a violem. Neste caso, sempre que uma nova população for gerada, indivíduos que violem a restrição em (5) são descartados e a nova população é composta apenas por soluções viáveis.

É importante também observar que a função de aptidão adotada indica quanto o valor da função objetivo obtida com o acréscimo das perdas pelo AG representa, em termos percentuais, quando comparada ao valor da função objetivo obtida quando as perdas na baixa tensão não são consideradas.

3.4 Algoritmo

A população inicial do AG é obtida de forma aleatória, ou seja, através da inicialização dos vetores $\Delta\mathbf{Perd}$ por meio do sorteio dos valores de cada um de seus elementos (correspondentes a perdas ativa ou reativa em uma determinada barra) e considerando uma distribuição uniforme no intervalo entre zero e um dado percentual do valor total da carga agregada sem perdas. Tal limite superior está de acordo com a restrição definida em (5). A partir de então, a aptidão de cada indivíduo é calculada pela aplicação da função aptidão (6). Uma vez calculada a aptidão de todos os indivíduos, são realizadas operações genéticas (seleção, cruzamento e mutação) para a obtenção da população da próxima geração. Neste processo, também é considerado o operador de elitismo, de modo que o indivíduo com maior aptidão na geração anterior é sempre preservado na população da geração seguinte. Ao ser atingido o número máximo de gerações, definido como critério de parada para o AG, o indivíduo mais apto da última geração é apresentado como a solução do problema de otimização.

Conforme mencionado anteriormente, a não consideração das perdas afeta os resultados obtidos pelo estimador de estado, refletindo-se em um maior valor da função objetivo $J(\mathbf{x})$ da EE, a qual no processo de estimação é minimizada utilizando-se o método dos mínimos quadrados ponderados. Portanto, caso a otimização pelo AG seja bem sucedida, é esperado que o valor de $J(\mathbf{x})$ obtido sem a consideração das perdas nas barras que agregam MI seja melhorado com a agregação também das perdas obtidas no processo evolutivo pelo AG.

O fluxograma que descreve o processo evolutivo para obtenção das perdas que somadas às medidas obtidas pela agregação de MI levam à minimização da função objetivo da estimação de estado $J(\mathbf{x})$ é mostrado na Figura 2.




Figura 2 – Fluxograma do processo evolutivo

4. Testes e Resultados

Nas seções seguintes é descrita a realização de testes com a aplicação da metodologia proposta. Detalhes sobre a simulação realizada e os resultados obtidos utilizando-se dados de um sistema de distribuição típico extraído da literatura são apresentados.

4.1 Descrição da simulação

Testes foram realizados utilizando o sistema trifásico desequilibrado de 34 barras ilustrado na Figura 3 [Soares et al. 2019]. O sistema de medição coleta medidas de fluxo e injeção de potência ativa e reativa, tendo sido considerado que em algumas delas as medidas coletadas correspondem apenas às obtidas pela agregação de medidas de MI, sem estarem aí contabilizadas as perdas. O processo de EE foi realizado utilizando-se um programa desenvolvido em Python para realizar a estimação de estado em sistemas elétricos de distribuição trifásicos desequilibrados. Vale

ressaltar que, embora a rede utilizada para simulações neste trabalho seja trifásica desequilibrada, o programa computacional para EE e a metodologia proposta podem também ser aplicados a sistemas elétricos trifásicos equilibrados.

Optou-se por testar uma rede trifásica desequilibrada por este ser o caso mais comum em sistemas de distribuição de energia elétrica. Para a implementação da metodologia proposta e realização das simulações, foi construído um programa em Python, que utilizou o AG da biblioteca MEALPY [Thieu e Mirjalili. 2023]. Nas simulações foi empregado um computador com processador Intel Core i7-7500U CPU, 2.90 GHz, 8 GB de memória RAM, sistema operacional Windows 10 64 bits.




Figura 3 – Rede trifásica desequilibrada

4.2 Resultados

Testes foram realizados considerando que em quatro barras da rede as medidas coletadas correspondem à valores agregados de medidas de MI. Nas simulações, diferentes configurações para os parâmetros do AG foram testadas. A seguir são apresentados resultados obtidos quando as medidas de MI agregadas estavam todas localizadas no tronco principal do alimentador da rede de distribuição (barras 2, 4, 5 e 8) e também resultados obtidos com as medidas agregadas majoritariamente localizadas em barras dos ramais laterais da rede (barras 4, 15, 30 e 31).

A Figura 4 apresenta a evolução da aptidão da melhor solução a cada geração quando se considerou a presença de medidas agregadas de MIs nas barras 2, 4, 5 e 8. São apresentados resultados para diferentes valores testados para as taxas de cruzamento e mutação. É possível perceber que com a aplicação da metodologia proposta foi possível obter uma melhoria significativa da aptidão das soluções propostas pelo AG e, conseqüentemente, da função objetivo da estimação de estado. Os melhores resultados foram alcançados com probabilidade de cruzamento (pc) em 95% e probabilidade de mutação (pm) em 2,5%.




Figura 4 – Resultados para medidas agregadas nas barras 2, 4, 5 e 8

Os valores das potências por fase nas barras 2, 4, 5 e 8, medidos, estimados e verdadeiros, são apresentados na Tabela 1. Os valores medidos são aqueles agregados sem considerar as perdas, os valores estimados são os obtidos pelo AG com as perdas estimadas adicionadas aos valores medidos e os valores verdadeiros correspondem aos valores reais da carga em cada barra, já incluindo as perdas. Os valores das medidas de potência ativa estão expressos em MW, enquanto os valores das medidas de potência reativa são apresentados em MVar. O estado estimado pela EE corresponde ao vetor de correntes nos ramos da rede. Para avaliar a melhoria do estado estimado com a consideração das perdas, foi calculado o Erro Vetorial Total (EVT) conforme a equação (7), onde os valores de referência são as correntes verdadeiras nos ramos, ou seja, estimadas a partir das medidas consideradas verdadeiras. A Tabela 2 apresenta o máximo EVT para as estimativas de estado nas fases a, b e c, considerando duas situações: (i) agregando as perdas obtidas pelo AG e (ii) sem considerar a agregação das perdas. Todos os cálculos foram realizados considerando as grandezas expressas em valores por unidade (p.u.). A melhoria da função objetivo da EE e da qualidade do estado estimado ficou evidenciada quando se considerou as perdas obtidas pelo AG. No processo evolutivo, os melhores resultados foram alcançados com probabilidade de cruzamento em 95% e probabilidade de mutação em 2,5%.

$$EVT = \sqrt{\frac{(x_{rest} - x_{ref})^2 + (x_{iest} - x_{iref})^2}{x_{ref}^2 + x_{iref}^2}} \quad (7)$$

onde:

x_{rest} e x_{iest} – partes real e imaginária do estado estimado;

x_{ref} e x_{iref} – partes real e imaginária do valor de referência.

Tabela 1 – Grandezas por fase nas barras 2, 4, 5 e 8 (medidas, estimadas e verdadeiras)

Fase		a			b			c		
Bar	Pot.	med	AG	verd	med	AG	verd	med	AG	verd
2	P	209,3	219,8	230,0	212,9	219,6	234,0	117,0	122,1	130,0
	Q	133,6	148,5	148,5	100,3	102,0	111,5	116,2	122,6	125,5
4	P	222,9	238,0	245,0	202,0	218,9	222,0	214,7	237,7	236,0
	Q	159,6	173,9	173,5	162,4	164,9	178,5	176,2	189,4	189,5
5	P	211,6	216,5	230,0	213,8	223,2	235,0	218,0	223,8	237,0
	Q	131,1	137,0	142,5	129,6	135,7	142,5	132,5	140,0	142,5
8	P	117,0	117,0	130,0	251,1	255,7	270,0	241,8	244,7	260,0
	Q	137,2	145,8	152,5	220,6	244,7	242,5	218,2	225,4	242,5

Tabela 2 – EVT máximo considerando medidas agregadas nas barras 2, 4, 5 e 8

Fase		a	b	c
Máximo EVT	Medidas + Δ Perd	0,0164	0,0183	0,0262
	Medidas	0,0335	0,0367	0,0347

As características de convergência do processo evolutivo quando se considerou a presença de medidas agregadas nas barras 4, 15, 30 e 31 podem ser vistas na Figura 5, quando se explorou diferentes valores para as taxas de cruzamento e mutação. Neste caso, os melhores resultados foram obtidos com probabilidade de cruzamento em 90% e probabilidade de mutação em 2,5%.




Figura 5 – Resultados para medidas agregadas nas barras 4, 15, 30 e 31

Mais uma vez, uma melhoria significativa da função objetivo da EE e da qualidade do estado estimado foi perceptível quando as perdas estimadas pelo AG foram somadas às medidas, conforme pode ser visto nos resultados das Tabelas 3 e 4.

Tabela 3 – Grandezas por fase nas barras 4, 15, 30 e 31 (medidas, estimadas e verdadeiras)

Fase		a			b			c		
Bar	Pot.	med	AG	verd	med	AG	verd	med	AG	verd
4	P	222,9	226,7	245,0	202,0	205,0	222,0	214,7	215,2	236,0
	Q	159,6	162,6	173,5	162,4	165,4	178,5	176,2	176,6	189,5
15	P	65,5	69,3	72,0	66,2	69,2	72,0	65,2	68,0	72,0
	Q	40,9	41,4	45,0	41,8	42,1	45,0	40,5	41,9	45,0
30	P	69,0	71,9	75,0	87,4	91,2	95,0	79,0	79,5	85,0
	Q	43,2	47,9	48,0	34,4	38,2	37,0	53,6	53,9	59,0
31	P	51,8	56,2	57,0	51,8	53,7	57,0	52,4	56,2	57,0
	Q	33,7	36,7	37,5	33,7	36,7	37,5	34,1	34,2	37,5

Tabela 4 – EVT máximo considerando medidas agregadas nas barras 4, 15, 30 e 31

Fase		a	b	c
Máximo EVT	Medidas + Δ Perd	0,0411	0,0495	0,0731
	Medidas	0,0865	0,0933	0,0771

5. Conclusões

Os sistemas de distribuição de energia elétrica têm passado por transformações intensas nos últimos anos, sendo fundamental sua supervisão por meio de um processo de estimação de estado. Vislumbra-se também que um grande volume de dados para processamento se torne disponível, a maior parte de tais dados proveniente de medidores inteligentes. Porém, devido a questões regulatórias e de privacidade, existe a tendência de que dados de medidores inteligentes estejam disponíveis apenas agregados na média tensão, não sendo desta forma contabilizadas as perdas elétricas na baixa tensão, com efeitos deletérios sobre o resultado da estimação de estado. Este trabalho apresenta uma metodologia baseada em algoritmos genéticos para a realização da estimação de estado em redes de distribuição em que parte das medidas disponíveis é obtida pela agregação de informações coletadas de medidores inteligentes. Um algoritmo genético é empregado para a obtenção dos valores de perdas a serem acrescentados aos valores agregados de medidas de medidores inteligentes e, consequentemente, melhorar os resultados obtidos pelo estimador de estado. Resultados obtidos após a realização de testes com um sistema de distribuição típico da literatura foram apresentados para ilustrar a aplicação da metodologia proposta e mostrar seu efeito positivo sobre os resultados da estimação de estado.

Referências

- Abur, A. e Gómez-Expósito, A. (2004). Power System State Estimation: Theory and Implementation, Marcel Dekker, New York.
- Arritt, R. F. e Dugan, R. C. (2011). Distribution system analysis and the future smart grid, *IEEE Trans. Ind. Appl.*, 47:2343–2350.

Baran, M. e Kelley, A. (1995). A branch-current-based state estimation method for distribution systems, *IEEE Trans. Power Syst.*, 10:483–491.

Chen, Q., Kaleshi, D., Fan, Z. and Armour, S. (2016). Impact of smart metering data aggregation on distribution system state estimation, *IEEE Trans. Ind. Informat.*, 12:1426–1437.

Della Giustina, D., Pau, M., Pegoraro, P., Ponci, F. e Sulis, S. (2014). Electrical distribution system state estimation: measurement issues and challenges, *IEEE Instrum. Meas. Mag.*, 17:36–42.

Dugan, R. C., Artritt, R. F., McDermott, T. E., Brahma, S. M. e Schneider, K. (2010). Distribution system analysis to support the smart grid, In *Proc. of the Power and Energy Society General Meeting*, p. 1-8, Minneapolis, Minnesota, USA, IEEE.

Galvin, R. e Yeager, K. (2009). Perfect Power: How the Microgrid Revolution Will Unleash Cleaner, Greener and More Abundant Energy, McGraw-Hill, New York.

Heydt, G. T. (2010). The next generation of power distribution systems, *IEEE Trans. Smart Grid*, 1:225–235.

Lefebvre, S., Prevost, J. e Lenoir, L. (2014). Distribution state estimation: A necessary requirement for the smart grid, In *Proc. IEEE PES General Meeting Conf. Expo.*, p. 1–5, National Harbor, MD, USA, IEEE.

Monticelli, A. (1999). Power System State Estimation: A Generalized Approach, Kluwer Academic Press, Massachusetts, USA.

OSI: Advanced Distribution Management Systems. Webpage: <http://www.osii.com/solutions/products/distribution-management.asp> . Acessado: 2024-05-16.

Singh, R., Pal, B. C. and Jabr, R. A. (2009). Choice of estimator for distribution system state estimation, *IET Gener. Transm. Distrib.*, 3:666–678.

Soares, W. S., Stacchini de Souza, J. C., Do Coutto Filho, M. B. e Augusto, A. A. (2019). Distribution System State Estimation using Real-Time Pseudo-Measurements, In *Proc. IEEE PES Innovative Smart Grid Technology Latin America*, p. 1-5, Gramado, Brazil, IEEE.

Thieu, N. V., Mirjalili, S. (2023). MEALPY: An open-source library for latest meta-heuristic algorithms in Python, *Journal of Systems Architecture*, Vol. 139, 102871, ISSN 1383-7621.